05 | 直方图与幂分布：为什么全世界1%的人掌握着50%的财富？

2021-08-06 郭炜

《数据分析思维课》 课程介绍 >

讲述：郭炜

时长 13:34 大小 12.43M

数据给你一双看透本质的眼睛，这里是《数据分析思维课》，我是郭炜。

我们之前讲了各种从数据结论中去伪存真的办法，我们今天更进一步，来看看当数据摆在你面前的时候，你应该如何从数据当中发现特征？

今天我就教给你一个最简单的办法——直方图。

你可能会有类似这样的想法：直方图还不简单，不就是柱状图吗？一个 Excel 就搞定了我天天画柱状图。

但这种想法是错误的，因为直方图并不等于柱状图。现在请你花一分钟时间，仔细看看下面这两个图表，你能分辨出哪个是直方图，哪个是柱状图吗？

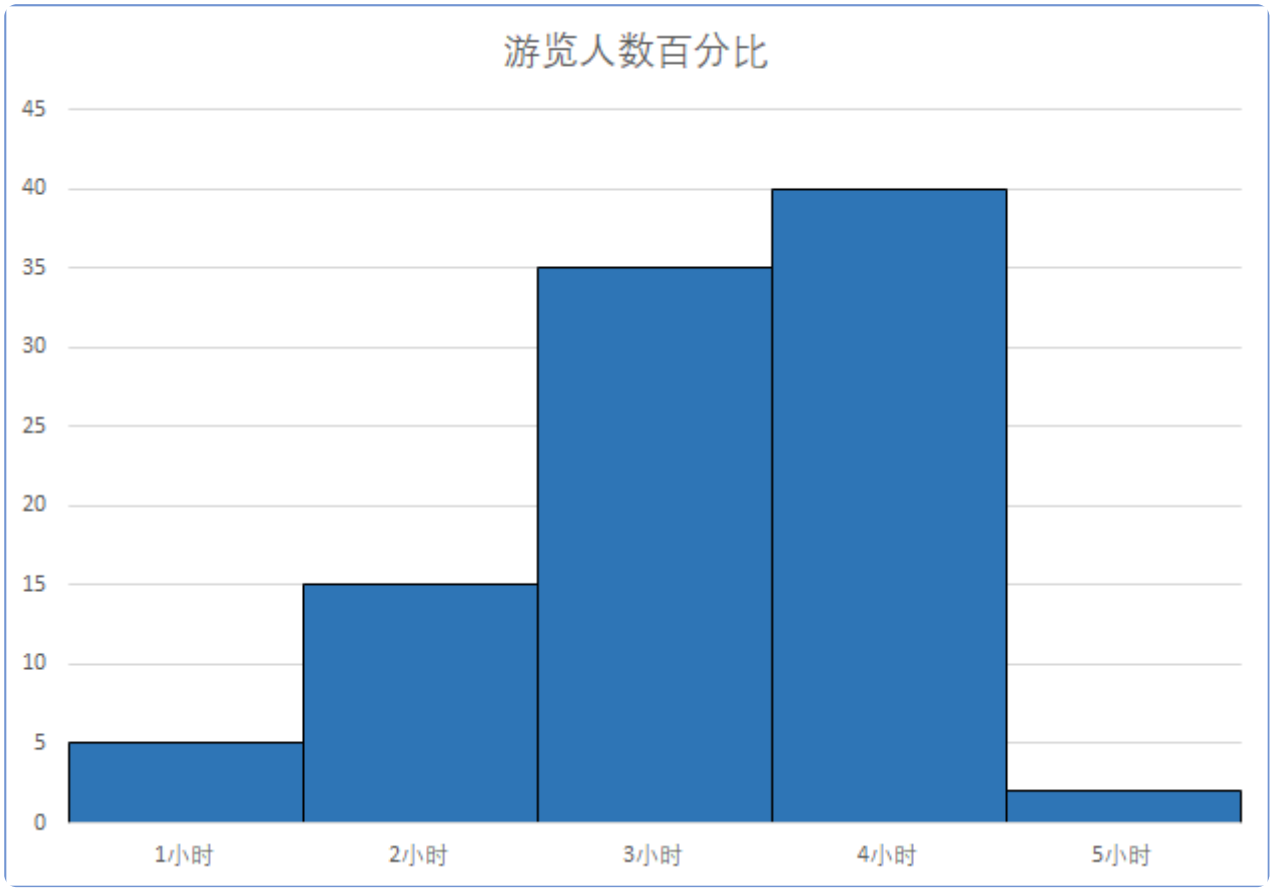

北京动物园日平均参观时长

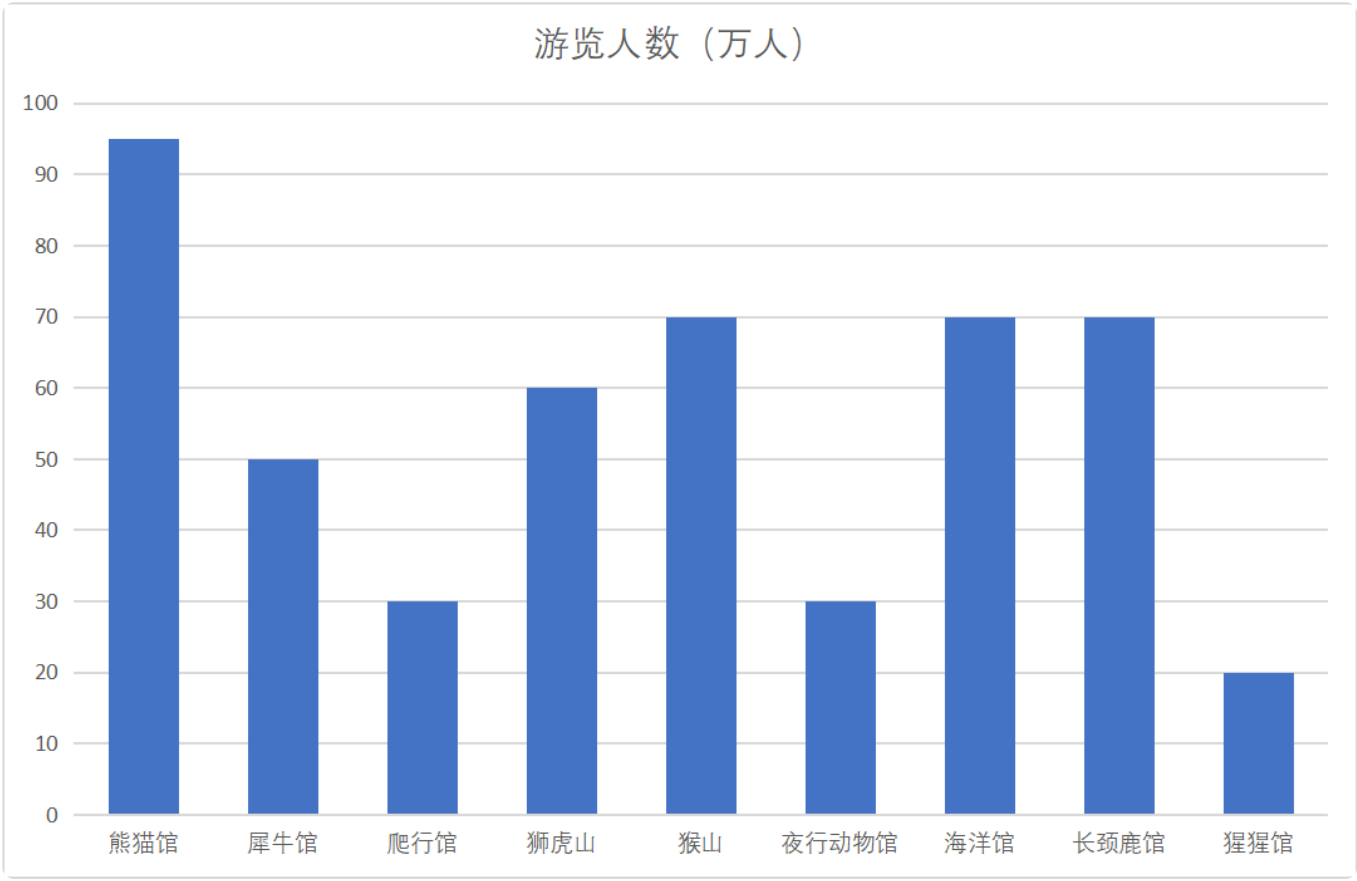

北京动物园日场馆平均参观人数

直方图与柱状图

答案是第一个图（动物园平均参观时长）为直方图，第二个图（动物园平均参观人数）为柱状图。

看上去上面这两幅图都是用直直方方的图形来展示，但其实它们是两种完全不同的图形展现和数据分析方法。那问题来了，我们如何才能分清楚直方图和柱状图呢？

我教你一个最简单的办法：**直方图是展示数据的分布，而柱状图是比较数据的大小。**

更具体点来说，直方图的 X 轴是定量的数据或者区域数据（用于看分布），而柱状图 X 轴是分类的数据。就拿刚刚的这两个图来说，第一个图其实是 X 轴是**人们观光动物园的时间分布**，而第二个图的 X 轴是**人们去动物园场馆的具体分类**。

直方图是针对定量数据分布的定性分析，柱状图是对分类数据的定量数据分析，这两兄弟长得很像，用途也是互为补充。在第一个图里你能看到有 40% 的游客是停留了 4 个小时，但无法知道每天有多少游客去动物园。而在第二个图里，你能够知道大概每天会有 95 万名游客去了熊猫馆，但不能够看到游客的游览时间分布情况。

你也可以从表现形式上来对直方图与柱状图加以区分。

从柱子的间隔上来说，直方图的柱子和柱子之间没有间隔，而柱状图之间柱子是有间隔的。从柱子的宽度上来讲，直方图的柱子宽度可以不一样，而柱状图的柱子宽度必须一样。

对直方图来说，它的柱子宽度代表区间的长度，根据区间的不同，柱子宽度可以不同。但柱状图的柱子宽度没有数值含义，所以宽度必须一致。你可以看看下面的这张图，这是美国人口普查局（The U.S. Census Bureau）调查 12.4 亿人的上班通勤时间的直方图，最后右侧的直方柱子就像一个矮胖子一样，直接蹲在地板上了。

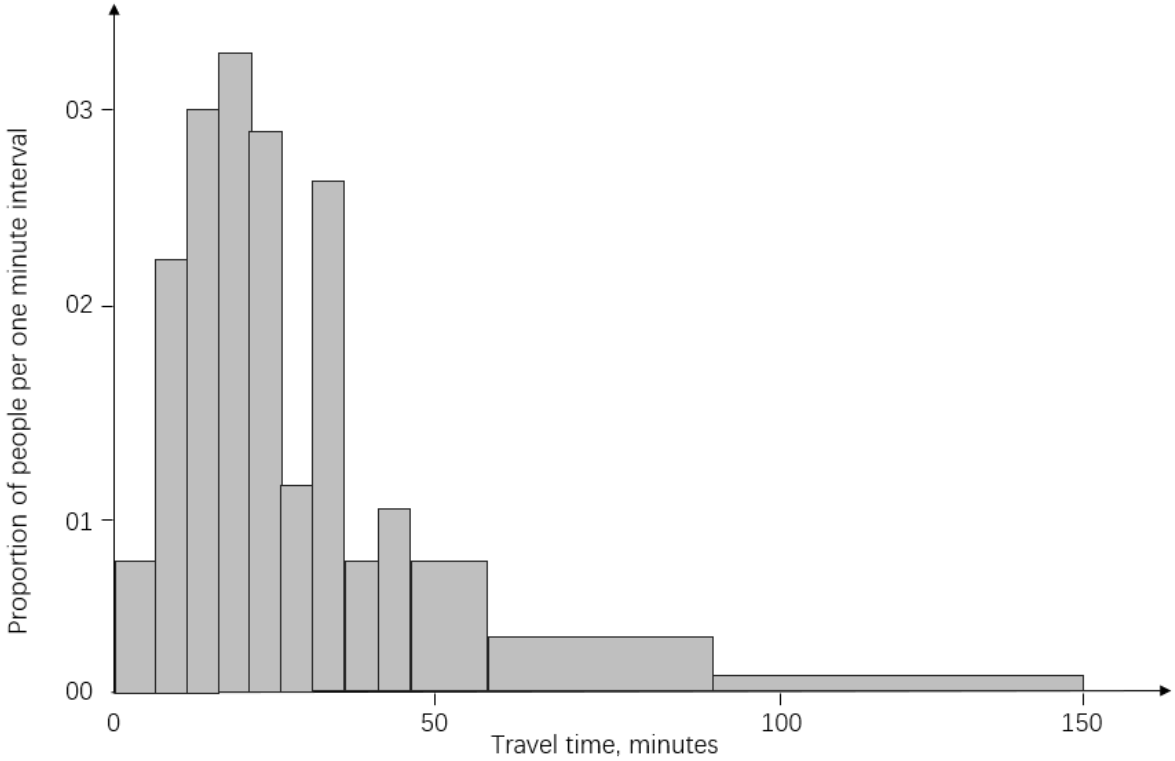

Histogram of travel time, US 2000 census. Area under the curve equals 1.
This diagram uses Q/Total/width from the table.

图片来源：福布斯《A Histogram is NOT a Bar Chart》

神奇的直方图

教你分辨完直方图与柱状图后，我们再来聊聊直方图。直方图最早是由数据统计学家 Karl Pearson 在 1891 年引入，它可以用来统计现实生活中各种各样的数据分布情况。

那具体直方图我们要怎么使用呢？你在搞不清楚某些数据的情况的时候。就可以把它画成一个直方图，然后就能够看到其中的规律了。举个例子，你可以看看下面这组数据，这是来自 2021 年截至 4 月底，所有的新冠肺炎疫情国家的累计发病人数。

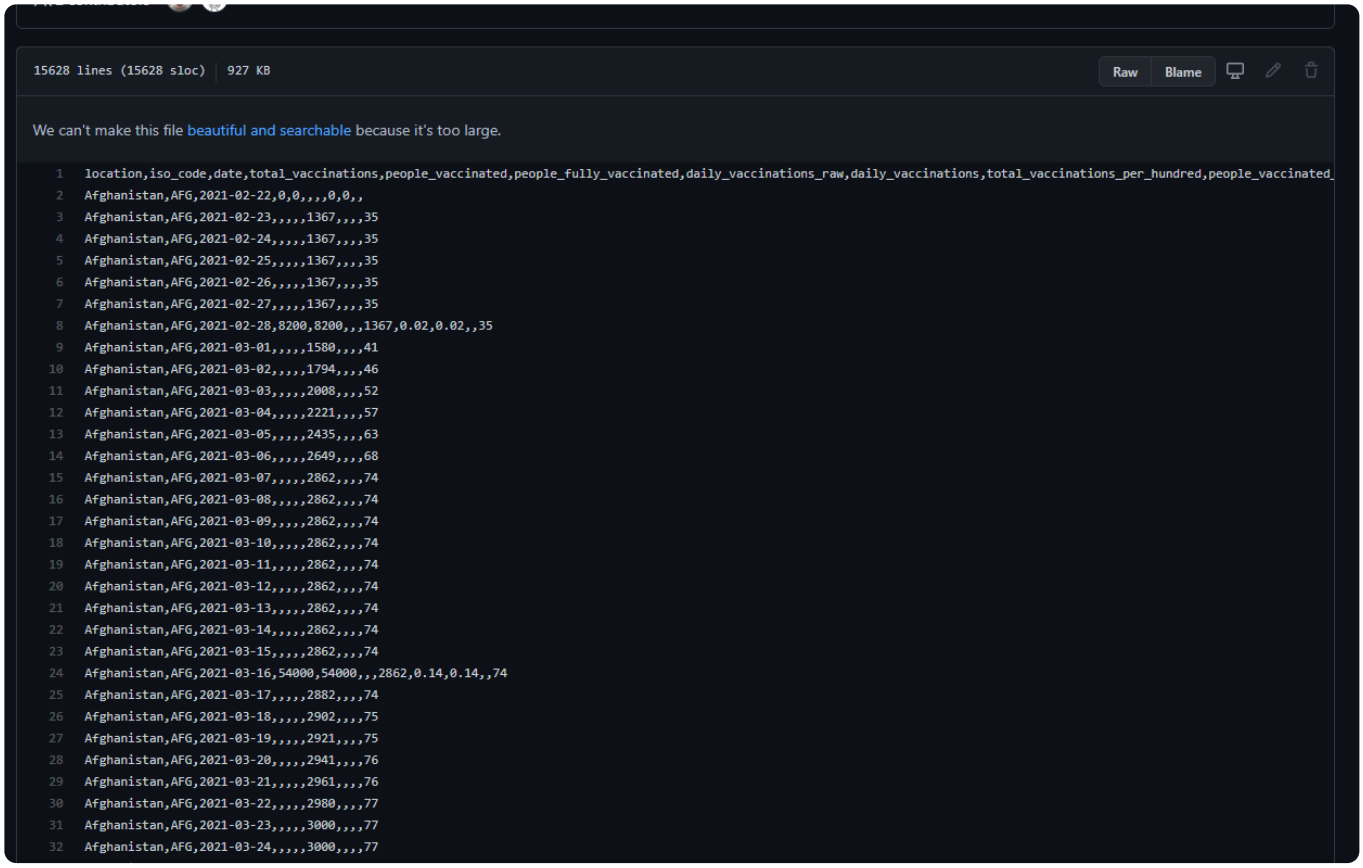

15628 lines (15628 sloc) | 927 KB

Raw Blame

We can't make this file beautiful and searchable because it's too large.

```
location,iso_code,date,total_vaccinations,people_vaccinated,people_fully_vaccinated,daily_vaccinations_raw,daily_vaccinations,total_vaccinations_per_hundred,people_vaccinated_
Afghanistan,AFG,2021-02-22,0,0,,,,0,0,,
Afghanistan,AFG,2021-02-23,,,,,1367,,,,35
Afghanistan,AFG,2021-02-24,,,,,1367,,,,35
Afghanistan,AFG,2021-02-25,,,,,1367,,,,35
Afghanistan,AFG,2021-02-26,,,,,1367,,,,35
Afghanistan,AFG,2021-02-27,,,,,1367,,,,35
Afghanistan,AFG,2021-02-28,8200,8200,,,1367,0.02,0.02,,35
Afghanistan,AFG,2021-03-01,,,,,1580,,,,41
Afghanistan,AFG,2021-03-02,,,,,1794,,,,46
Afghanistan,AFG,2021-03-03,,,,,2008,,,,52
Afghanistan,AFG,2021-03-04,,,,,2221,,,,57
Afghanistan,AFG,2021-03-05,,,,,2435,,,,63
Afghanistan,AFG,2021-03-06,,,,,2649,,,,68
Afghanistan,AFG,2021-03-07,,,,,2862,,,,74
Afghanistan,AFG,2021-03-08,,,,,2862,,,,74
Afghanistan,AFG,2021-03-09,,,,,2862,,,,74
Afghanistan,AFG,2021-03-10,,,,,2862,,,,74
Afghanistan,AFG,2021-03-11,,,,,2862,,,,74
Afghanistan,AFG,2021-03-12,,,,,2862,,,,74
Afghanistan,AFG,2021-03-13,,,,,2862,,,,74
Afghanistan,AFG,2021-03-14,,,,,2862,,,,74
Afghanistan,AFG,2021-03-15,,,,,2862,,,,74
Afghanistan,AFG,2021-03-16,54000,54000,,,2862,0.14,0.14,,74
Afghanistan,AFG,2021-03-17,,,,,2882,,,,74
Afghanistan,AFG,2021-03-18,,,,,2902,,,,75
Afghanistan,AFG,2021-03-19,,,,,2921,,,,75
Afghanistan,AFG,2021-03-20,,,,,2941,,,,76
Afghanistan,AFG,2021-03-21,,,,,2961,,,,76
Afghanistan,AFG,2021-03-22,,,,,2980,,,,77
Afghanistan,AFG,2021-03-23,,,,,3000,,,,77
Afghanistan,AFG,2021-03-24,,,,,3000,,,,77
```

是不是如果只看这幅图，你会感觉满屏都是数字，不知道如何下手，更别说得出什么结论了。

但是当我们用直方图把这些数字给表示出来的时候，神奇的事情发生了。你会清晰地发现，拿全球所有的国家这个范围来看，其实绝大部分的病例都发生在极少数的国家里，就像下面这幅图一样。

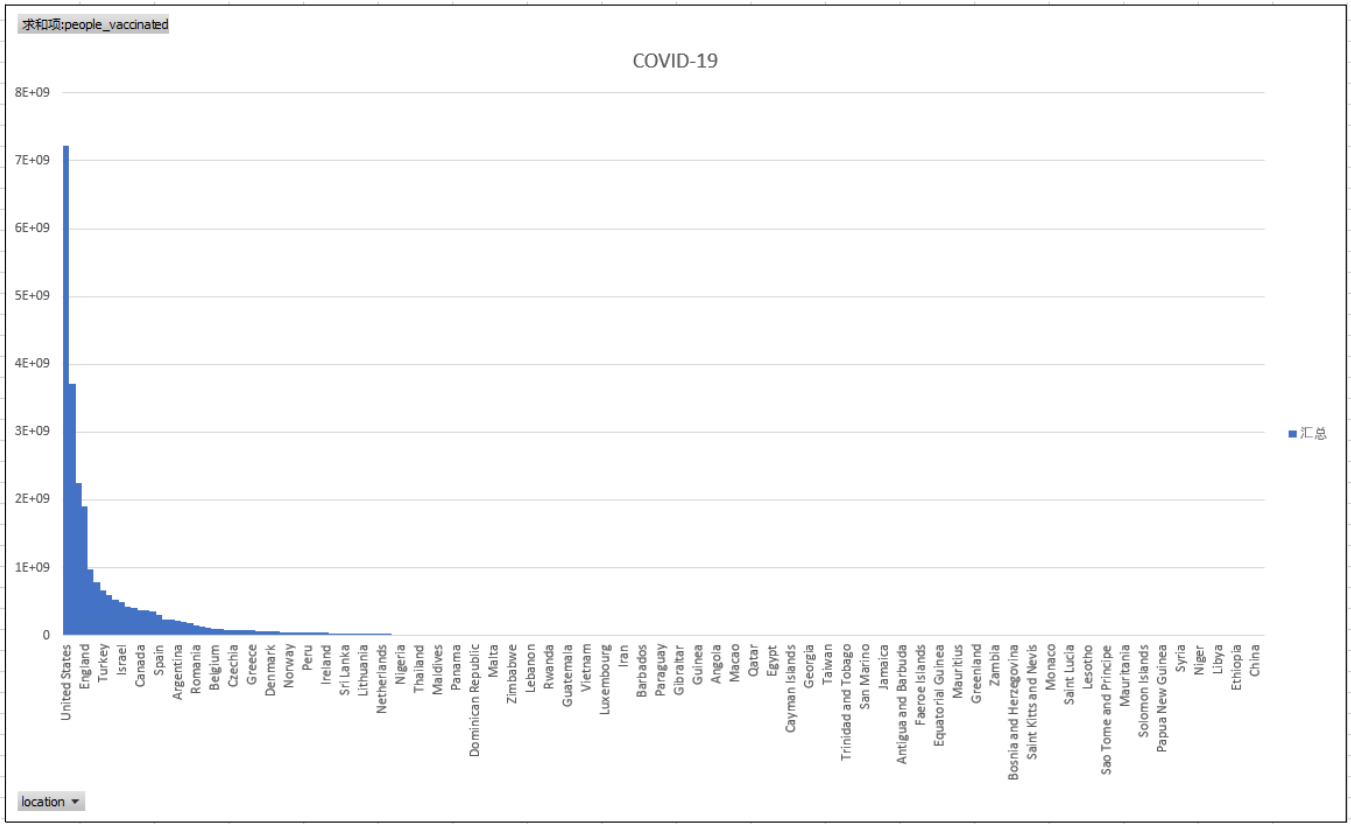

而且这样的分布并不是个例，我们现在把目光转向亚马逊丛林。

亚马逊地区有着全球树种最丰富的雨林，科学家已将亚马逊地区将近 16000 种树种编入物种目录。尽管亚马逊雨林呈现出如此多彩的物种多样性，科学家们还是发现在其中有 227 种树种牢牢占据主导地位，这些树种的分布面积几乎占到了整个亚马逊雨林面积的一半，也就是说仅 1.4% 的树种就占据了整个地区的 50%，画出图来也和上面的图形类似。

这种从直方图体现出来呈指数下降或者上升的分布形式，科学家们把它叫做“幂律分布”。

幂律分布与帕累托法则

幂率分布也叫做指数分布，你会发现在这种分布里，X 轴的开始的地方数值很高（或很低），然后以指数级的下降（或上升）到 X 轴的末尾段，按照统计学定义叫做：“分布密度函数是幂函数的分布”。

这样的规律其实无处不在，拿我们日常使用的词汇来说，你自己最常用的词汇往往就是那些 500~1000 个词，其余的词汇少量或者更少量在书面时候使用，如果你把你自己的用词数做一个直方图，你会发现语言的词汇使用率也是呈幂律分布的。

不止中文、英文，其实全球语言使用的词汇其实都是服从幂律分布的。所以我们在学外语的时候，经常看到要背会最常用的多少个单词。比如大学英语你去考 4 级 6 级 8 级，很多词汇书上会写着“超实用 XX 词速记”“XX 词随身带”，这些词汇书就是基于语言的幂律分布，来帮助我们更好地学习外语。

那么这种现象是怎么产生的呢？

病毒、树种和语言其实都有一个共性——传播性。比如在亚马逊雨林里，两株植物长在了一块，那么每天这两株植物就要为阳光和土壤中的养分去竞争。如果其中一株能比另外一株植物每天稍微长快一点，那么它就能长得更高，从而获得更多的阳光、吸收更多的养分。

如果每天都有这些额外的能量，这株植物就更加有能力把种子给传播出去，然后复制这种模式。一直持续下去，这种植物就会积累出得天独厚的优势。

在语言的使用和病毒的传播当中也是同理。开始的微妙的优势会随着时间逐步加强，最后就能占领绝对优势，就像滚雪球一样，越滚越大。拿美国来说，它的医疗水平能力确实很强，但是由于美国对待疫情的态度并不够重视，病毒在美国其实是占据传播的优势的。所以强如美国，最后也被新冠给好好上了一课。

说到幂律分布，那就不得不提一下帕雷托法则了。你或许对帕累托法则有些陌生，但我要是说二八法则，你肯定听过。

二八法则简单来说，就是 20% 的人占了 80% 的资源，剩下 80% 的人分最后 20% 的资源。这个法则诞生于帕累托的花园。有一天帕累托偶然发现，自己园子里绝大部分的豌豆是由园子里极少部分豌豆荚产生。

作为一名擅长数学的经济学家，帕累托意识到这里面大有玄机。于是他马上把这种现象应用到了生活的其他领域，他惊奇地发现，意大利人 80% 的土地仅掌握在 20% 的手的人的手中，就和园子当中的豌豆荚类似，于是发表了著名的“帕雷托法则”（也被人称之为“二八法则”）。这个法则的背后的规律就是幂律分布。

企业的竞争力也同样符合帕累托法则。举个例子，如果我们把全网短视频 APP 的月活用户用柱状图表示出来，你会发现同样符合幂律分布。就像文稿里的这张图这样，比较高的

APP 的月活会高于均值很多倍，第一名、第二名分掉了整体赛道流量的 90%。所以在互联网领域里才会有这么一句话：一个领域只有第一、第二，没有第三。

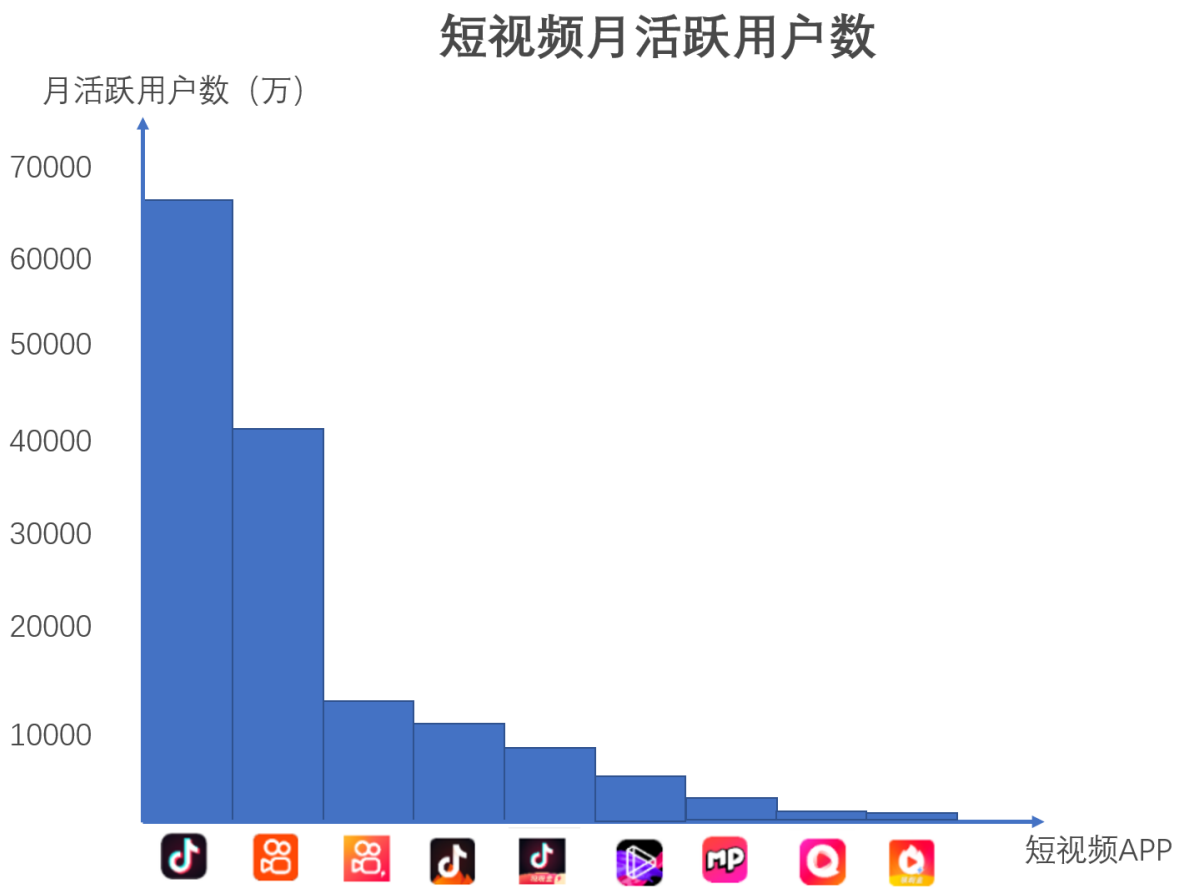

幂律分布与帕累托法则其实都强调了重要的少数和琐碎的多数，从某种意义上来讲，世界从来都不是平衡的。

所以在日常生活里，不要把所有事都放在同一个优先级上，而是学会用帕累托法则去看待问题，找出最重要的 20% 的问题，并最优先解决。同时，你也要留个心眼：为什么这 20% 的问题对你来说最为重要？

对应到工作中，你可以多想想以下几个问题。

> 在你一天的工作分配当中，由于 80% 的工作都是日常反馈，你是否安排了自己最清醒的时间去处理最重要的 20% 工作？
>
> 你所在的公司，是不是由 20% 的客户来为公司提供了 80% 的利润，如果是，应该如何留住这些客户？
>
> 在团队里，杰出贡献是 20% 的人做的，80% 的人是配合，那么针对这 20% 的人，你应该如何留住他们？

能否通过弥补 20% 的质量缺口去获得 80% 的收益（或者避免 80% 的客户投诉）？

在最有效的 20% 的时间内，如何引导团队做出 80% 的相关分析？

最后再来说说我们个人的发展。为什么有的人一开始和普通人差不多，但是他们后来渐渐地把同龄人甩在了身后？

有的人可能会觉得是因为这些人运气好，运气也是实力的一部分，但毕竟“幸运只光顾有准备的人”。你比其他人更努力，每天多积累 1% 哪怕是 0.1% 的优势，这样把优势不断积累下去，你就会占据越来越多的资源，成为这个领域里面的专家。

小结

好了，今天的课程到这里也就接近尾声了，我再来带你复习一下今天讲的内容。

今天我给你讲了两个重要的概念。一个是非常简单但有效的工具——直方图。直方图可以让你从混沌的数据里面找到其中的规律。很多的数据分布（包括下面几节课要讲的正态分布和拉普拉斯分布）都会用到这个工具。

紧接着我们从直方图讲到了幂律分布。这个统计学规律告诉我们，我们身处的世界是赢者通吃的世界，开始时细微优势最终将带来无穷多的回报。反之，最初的细微劣势也将导致最终一无所有。这个现象也有人称之为“马太效应”，在圣经《新约·马太福音》中是这样描述的：“凡有的，还要加给他，叫他多余。没有的，连他所有的也要夺过来”。

我们耳熟能详的帕雷托法则（也就是二八法则）、马太效应都是来自幂律分布。这个数字分布其实有很多点值得我们去思考，你可以尝试多在日常的工作以及生活里用一下它，或许能够给你一些意想不到的惊喜。

当然，帕累托法则给我带来最重要的一个认知更新是：每天在我们自己的专业领域里面，或者你的企业在所在的赛道里，只要你比其他人或者其他企业多成功 1%，最终积累起来的竞争优势将使别人无法超越，你就会变成那个能够大声说“我全都要”的少数派。

不积跬步，无以至千里；不积小流，无以成江海。数据给你一双看透本质的眼睛，让我们每天在数据这个领域里面比别人多 1% 的认知，最终看到一个和别人完全不同的世界。我们一起学习数据的规律，一起共勉！

课后思考

在你的工作生活当中，还有哪些事情你觉得符合帕累托法则或者幂律分布？背后的原因是什么？分享出来，我们一起共同提高！

分享给需要的人，Ta订阅后你可得 20 元现金奖励

赞 4 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 04 | 随机对照试验：章鱼保罗真的是“预言帝”么？

下一篇 06 | 数据分布：房子应该是买贵的还是买便宜的？

精选留言 (9)

写留言

Scott少聪@SequoiaDB
2021-08-06

二八法则简单来说，就是 20% 的人占了 80% 的资源，剩下 80% 的人分最后 20% 的资源。

你比其他人更努力，每天多积累 1% 哪怕是 0.1% 的优势，这样把优势不断积累下去，你就会占据越来越多的资源，成为这个领域里面的专家。...

展开

作者回复: 少聪说的对，哈哈哈

4

胖悟空
2021-08-07

课程中新冠的案例 是不是既可以用直方图也可以用柱状图表示？用柱状图表示的是不同国家新冠的人数比较。可以这样理解吗？

展开

作者回复: 可以，不过因为柱状图中间空隙比较大，不太容易看出来趋势，其实折线图也可以的，不用拘泥于工具，还是思路最重要

1

智仔
2021-08-06

每天只要增加0.1% ，时间一长，也会有惊人的成长。找好象就是原子习惯法则哈

作者回复: 哈哈，是的，所有的法则，算法背后哲理都是类似的

1

进化菌
2021-08-06

优秀终究是少数，高处不胜寒。
帕累托法则，适用于大量领域。比如做技术的人，能力排前面的占比不高，但是技术创新的天平却大大的倾斜在这少数人里面~

作者回复: 是的，所以他们占了80%的资源

1

夜路破晓
2021-08-10

天之道，损有余而补不足；人之道，损不足而济有余。越是自然形成的越符合正态分布，越是人为制造的越符合幂律分布。法天相地，终究不可得。然此不可得，正是有所得。得失之道，名为人道，实乃天道。

作者回复: 得数据之道！

mtfelix
2021-08-09

交作业：对孩子的正向反馈。

展开

作者回复: 的确，养娃也是积少成多的过程

芳菲

2021-08-09

前段时间做了一个行业调研，确实是绝大多数企业都在某两个突出的省份，剩下的就是每个省有几家，差别不太大。二八法则无疑了。

展开

作者回复: 是的，专注在优势省份，提高潜力省份的布局。

Geek_68a029

2021-08-06

第一次听二八法则是学数据结构与算法的时候，设计数据结构的时候只需要让20%的常用操作都很快，剩下的80%可以慢一些

展开

作者回复: 是的，抓大放小

那时刻

2021-08-06

请问老师显示直方图使用的工具是什么？

展开

作者回复: Excel就可以，在后续课程会教给大家。

1